



**UNIVERSITATEA „POLITEHNICA” din BUCUREȘTI**

**ȘCOALA DOCTORALĂ ETTI-B**

**Nr. Decizie 610 din 3 noiembrie 2020**

# **REZUMATUL TEZEI DE DOCTORAT**

## **TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ PENTRU AFACERI**

**Doctorand: Thitimanan Damrongsakmethee**

**Conducător de doctorat: Prof. Victor-Emil Neagoe**

### **COMISIA DOCTORALĂ**

Președinte	<b>Prof.dr.ing Gheorghe Brezeanu</b>	de la	<b>Univ. Politehnica București</b>
Conducător de doctorat	<b>Prof.dr.ing. Victor-Emil Neagoe</b>	de la	<b>Univ. Politehnica București</b>
Referent	<b>Prof.dr.ing.Alexandru Serbanescu</b>	de la	<b>Academia Technica Militara “Ferdinand I”</b>
Referent	<b>Prof.dr.ing Nicu Bizon</b>	de la	<b>Universitatea din Pitesti</b>
Referent	<b>Prof.dr.ing Mihai Ciuc</b>	de la	<b>Univ. Politehnica București</b>

**BUCUREȘTI 2020**

---

## Rezumat

Teza este dedicată aplicării tehnicilor de inteligență artificială pentru afaceri, în special pentru predicția financiară. Această lucrare se concentrează pe următoarele două direcții de cercetare: cotarea creditelor și predicția seriilor de timp financiare. Cotarea creditelor se referă la predicția riscului financiar și informarea factorului decizional managerial în domeniul afacerilor bancare. Calitatea analizei de risc poate afecta performanța financiară a băncii. Pentru cotarea creditelor, s-a experimentat un set de clasificatori (Multilayer Perceptron (MLP), arbori de decizie, Support Vector Machine (SVM), algoritmul C4.5 în cascadă cu AdaBoost), precum și tehnici de selecție a caracteristicilor (Principal Component Analysis (PCA) și ReliefF) . Pe de altă parte, tehnicile de predicție a seriilor de timp financiare sunt utile liderilor de afaceri și organizațiilor pentru a îmbunătăți deciziile cu privire la efectele viitoare schimbări prezise. S-au considerat predicția cursului valutar și, de asemenea, predicția pieței bursiere. Au fost alese două tehnici de rețele neurale pentru predicția seriilor de timp financiare: modelul NARX (Nonlinear Autoregressive Exogenous) și modelul Deep Learning LSTM (Long Short-Term Memory). Rezultatele cercetării au fost publicate; cinci lucrări au fost incluse în volumele unor conferințe internaționale indexate WOS și o șasea lucrare a fost publicată într-o revistă internațională indexată SCOPUS.

## Cuprins

Rezumat.....	i
Lista tabelelor.....	iii
Lista figurilor .....	v
1 Introducere .....	1
2 Background.....	1
3 Modele de clasificare și modele de predicție / Evaluarea performanțelor clasificatorilor și evaluarea performanțelor modelelor de predicție .....	2
3.1 Modele de clasificare .....	2
3.2 Modele de predicție .....	3
3.3 Evaluarea performanțelor clasificatorilor și ale modelelor de predicție .....	3
4 Tehnici de selecție a caracteristicilor aplicate pentru cotarea creditelor .....	4
4.1 Specificațiile setului de date.....	4
4.2 Modelele propuse de tehnici PCA și ReliefF aplicate pentru evaluarea creditelor.	5
4.3 Performanțele modelelor.....	6
5 Îmbunătățirea performanțelor tehnicii C4.5 utilizând o cascadă conținând AdaBoost și modelul MLP pentru cotarea creditelor .....	7
5.1 Specificațiile seturilor de date .....	7
5.2 Tehnici C4.5 și MLP .....	7
5.3 Rezultatele modelului propus .....	7
6 Utilizarea unui model de rețea neuronală exogenă neliniară autoregresivă (NARX-Nonlinear Autoregressive Exogenous) pentru predicția ratei de schimb valutar.....	9
6.1 Specificațiile setului de date.....	9
6.2 Arhitectura modelului NARX propus.....	9
6.3 Rezultatele modelului propus .....	10
7 Model neuronal Deep Learning Long Short Term Term Memory (DLSTM) pentru predicția ratei de schimb valutar .....	13
7.1 Specificațiile setului de date pentru predicția ratei de schimb valutar.....	14
7.2 Modelul neuronal DLSTM propus .....	14
7.3 Rezultatele experimentale ale modelului neuronal DLSTM .....	15
7.4 Comparație între rezultatele modelului neuronal DLSTM și modelul neuronal NARX .....	17
8 Model neuronal Deep Learning Long-Term Memory (Deep LSTM) pentru predicția prețurilor acțiunilor .....	17
8.1 Specificațiile setului de date .....	17
8.2 Modelul propus de rețea neuronală Deep LSTM .....	17
8.3 Rezultate experimentale ale modelului Deep LSTM .....	19
8.4 Rezultatele comparării modelului neuronal Deep LSTM cu alte modele.....	20
9 Concluziile și perspective .....	21
9.1 Concluzii .....	21
9.2 Perspective .....	22
9.3 Lista contribuțiilor originale.....	23
Referințe .....	23

## Lista tabelelor

Tabelul 3.1 Măsurile ale calității predicției pentru evaluarea modelului neuronal Deep LSTM..	4
Tabelul 4.1 Detaliile setului de date de credit german .....	4
Tabelul 4.2 Valorile proprii, varianța în spațiul transformat PCA și varianța cumulată.....	5
Tabelul 4.3 Ordonarea și ponderile caracteristicilor din setul de date de credit german.....	6
Tabelul 4.4 Rezultatele testelor pentru diferite modele de clasificare și tehnici de selecție a caracteristicilor: PCA, ReliefF, PCA + ReliefF și fără tehnică de selecție a caracteristicilor.....	6
Tabelul 5.1 Detaliile seturilor de date.....	7
Tabelul 5.2 Procentele seturilor de date (instruire/validare/test) .....	7
Tabelul 5.3 Rezultatele unui model de cotare a creditelor cu arborele de decizie C4.5 și arborele de decizie C4.5 urmat de tehnica AdaBoost.....	8
Tabelul 5.4 Cele mai bune rezultate experimentale ale modelului de cotare a creditelor MLP (atunci când este setat parametrul H = 6 straturi ascunse) .....	8
Tabelul 5.5 Rezultatele comparării performanțelor modelului C4.5 (C4.5 și C4.5 urmat de tehnica AdaBoost) și ale modelului MLP.....	8
Tabelul 6.1 Volumul setului de date și procentele seturilor de instruire, validare și test .....	9
Tabelul 6.2 Cele mai bune rezultate ale arhitecturii modelului neuronal NARX.....	10
Tabelul 6.3 Rezultatele experimentale (setarea numărului de neuroni hidden (H) la 10, a numărului de întârzieri ale intrării ( $d_x$ ) și a numărului de întârzieri ale ieșirii ( $d_y$ ) la 4 ( $H = 10$ , $d_x = d_y = 4$ ).....	11
Tabelul 6.4 Cele mai bune rezultate experimentale pentru un număr de intrări egal cu numărul de ieșiri $N = 3$ (rata inflației, rata dobânzii, produsul intern brut) în funcție de numărul de neuroni ascunși H și de numărul de întârzieri ale intrării și ieșirii ( $N = 3$ , $d_x = d_y = 1:4$ ).....	11
Tabelul 6.5 Rezultatele experimentale pentru $N = 3$ intrări și $H=10$ neuroni ascunși în funcție de numărul de întârzieri $d_x = d_y$ .....	12
Tabelul 6.6 Cele mai bune rezultate experimentale ( $H = 10$ , $d_x = d_y = 3$ ).....	12
Tabelul 7.1 Detalii despre setul de date ale cursului de schimb valutar ale bahtului thailandez față de USD (volum de date și rapoarte procentuale ale loturilor de antrenare și test.....	14
Tabelul 7.2 Detalii despre straturile modelului de rețea neuronală DLSTM.....	15
Tabelul 7.3 Rezultatele experimentale ale variantelor A și respectiv B de experimente în funcție de numărul de iterații (modelul rețelei neuronale DLSTM are 3 straturi principale LSTM cu un număr corespunzător de neuroni de 50, 100 și 150).....	16
Tabelul 7.4 Comparare între rezultatele modelului neuronal DLSTM propus și modelul neuronal NARX.....	17
Tabelul 8.1 Detalii despre seturile de date referitoare la prețurile acțiunilor.....	17
Tabelul 8.2 Detaliile straturilor modelului neuronal Deep LSTM.....	19
Tabelul 8.3 Parametrii modelului neuronal Deep LSTM.....	19
Tabelul 8.4 Rezultatele experimentale ale modelului neuronal LSTM cu 4 straturi principale LSTM corespunzătoare numărului de neuroni (100.150.200 și 250).....	19
Tabelul 8.5 Rezultatele modelului neuronal LSTM propus, prin comparație cu alte modele pentru setul de date al indicelui Dow Jones Industrial.....	20

Tabelul 8.6 Rezultatele comparației modelului de rețea neuronală Deep LSTM propus cu alte modele pentru setul de date corespunzând indicilor S și P 500.....	21
--	----

## Lista figurilor

Fig. 4.1 Modelul propus de selecție a caracteristicilor bazat pe PCA și ReliefF pentru evaluarea creditelor.....	5
Fig. 5.1 Modelul propus constând din cascada C4.5 + AdaBoost pentru cotarea creditelor...	7
Fig. 5.2 Modelul MLP.....	7
Fig. 6.1 Arhitectura modelului neuronal NARX.....	10
Fig. 6.2 Configurarea modelului neuronal NARX.....	10
Fig. 6.3 Răspunsul seriei temporale pentru modelul neuronal NARX.....	13
Fig. 6.4 Histogramă de eroare a modelului neuronal NARX.....	13
Fig. 6.5 Cea mai bună performanță de validare a modelului neuronal NARX .....	13
Fig. 6.6 Regresia de eroare a modelului neuronal NARX.....	13
Fig. 7.1 Structura modelului neuronal DLSTM propus.....	14
Fig. 7.2 Cadrul arhitecturii modelului neuronal DLSTM.....	15
Fig. 7.3 Comparație între rezultatele observate și prognozate și eroarea MSE din seria A de experimente.....	16
Fig. 7.4 Comparație între rezultatele observate și prognozate și eroarea MSE din seria B de experimente.....	16
Fig. 8.1 Cadrul modelului neuronal Deep LSTM.....	18
Fig. 8.2 Arhitectura modelului Deep LSTM pentru predicția prețului acțiunilor.....	18
Fig. 8.3 Rezultatele comparative ale datelor originale cu prețurile de închidere prognozate pe setul de date de testare Dow Jones Industrial (precizia prognozei de 83,62%).....	20
Fig. 8.4 Rezultatele comparative ale datelor originale cu prețurile de închidere prognozate pe setul de date de testare al indicilor S și P 500 (precizia prognozei de 85,86% ).....	20

## Capitolul 1 Introducere

Această teză este realizată cu scopul de a studia și dezvolta tehnici (algoritmi) folosite pentru aplicarea învățării automate pentru afaceri. Cercetarea s-a axat pe tehnici de clasificare bazate pe *machine learning* ca parte a inteligenței artificiale, cum ar fi modelele Multilayer Perceptron (MLP), Support Vector Machine (SVM) și arbori de decizie C4.5, care sunt utilizați pentru cotarea creditelor. Pentru a rezolva problemele clasificării, această cercetare își propune să compare performanța modelelor propuse și să găsească un model de clasificare cât mai bun. Cercetările au fost aplicate la utilizarea aplicațiilor de învățare automată în modele de prognoză pentru afaceri (business). Cercetarea s-a axat pe folosirea aplicațiilor de tip *machine learning* pentru predicția modelelor pentru business (afaceri). S-a folosit un model de rețea neuronală exogenă neliniară autoregresivă (NARX- Nonlinear Autoregressive Exogenous) pentru a prezice rata de schimb valutar. A fost aplicată tehnica Deep Learning în varianta modelului rețelei neuronale LSTM (Long Short-Term Memory) pentru a prognoza seria temporală a datelor financiare. Studiul contribuie la aplicarea diverselor tehnici pe modelele de învățare automată pentru companii. Această teză a studiat și proiectat tehnicile de *machine learning* cu componente inovatoare pentru a fi utilizate în afaceri, cum ar fi:

- 1) Tehnici de clasificare de tip *machine learning* pentru cotarea creditelor (credit scoring) și tehnici de clasificare aplicate versus selecție de caracteristici, precum și tehnici de selecție a caracteristicilor de tip Principal Component Analysis (PCA) și ReliefF pentru cotarea creditelor.
- 2) Aplicarea tehnicii algoritmul C4.5 în cascadă cu AdaBoost pentru cotarea creditelor.
- 3) Implementarea modelului NARX pentru a prezice ratele de schimb valutar.
- 4) Aplicarea tehnicilor Deep Learning în varianta LSTM pentru datele seriei temporale ale cursului de schimb valutar.
- 5) Implementarea tehnicii de predicție a modelului Deep Learning LSTM pentru piața indicilor bursieri.

## Capitolul 2 Background

În acest capitol vom rezuma principiile, teoriile și lucrările relevante utilizate în această cercetare. Conținutul capitolului explică semnificația, conceptele și procesele de notare a creditului și cercetările conexe ale tehnicilor de clasificare a notării creditului. Cercetarea a explicat informațiile de bază despre prognozele financiare, prognozele de bază ale pieței prețurilor bursiere și principiile de bază ale exploatarea datelor aplicate în acest studiu. Scorul de credit este o variabilă fundamentală pe care instituțiile financiare o utilizează ca instrument pentru a măsura comportamentul intenției solicitantului de credit de a rambursa datoriile, identificându-i pe cei expuși riscului, astfel încât instituțiile financiare să poată justifica creditul în mod eficient [1]. Această secțiune se bazează pe un set de 20 de lucrări de cercetare selectate dintr-o serie de reviste științifice riguroase, axate pe articole relevante, bazate pe tehnici de *machine learning* pentru cotarea creditelor și studii axate pe îmbunătățirea sau propunerea de noi abordări. Pentru această teză, detaliile datelor de cotare a creditelor sunt testate pentru diferite modele, utilizând datele reale disponibile colectate de la UCI-ML (University of California Irvine Machine Learning), și anume seturile German credit data și Australian credit data. Astăzi, aproape fiecare țară are noi afaceri care apar și încearcă să fie lideri în diverse domenii. Este bine cunoscut faptul că afacerile

de succes sunt deseori afaceri planificate în viitor. În general, cunoștințele statistice sunt adesea adăugate pentru a ajuta planificarea prin anticiparea evenimentelor viitoare, folosind analiza seriilor temporale [2]. Practic, analiza datelor seriilor de timp este o reglementare statistică care poate utiliza date curente sau evenimente, eventual date istorice, pentru a face predicții asupra viitorului [3]. De exemplu, departamentul de achiziții poate utiliza datele din experiența anterioară pentru a face predicții sau pentru a decide ce materiale să cumpere în următoarele trei luni [4]. Un alt exemplu: Autoritatea generatoare de energie electrică din Thailanda ar putea decide că reducerea facturilor la electricitate va crește cu o rată similară cu cea de acum un deceniu pentru a prognoza cererea în următorii 10 ani sau 20 de ani [5]. Din exemplul de mai sus, se poate găsi valoarea variabilelor pentru a prezice în multe perioade anterioare iar datele se numesc „serii de timp” și se poate numi metoda utilizată pentru această valoare de date ca „analiză a seriilor de timp”. Datele din seria temporală reprezintă o colecție de date colectate pe o perioadă continuă de timp, cum ar fi indicii zilnici ai pieței bursiere la închiderea tranzacției trimestriale a veniturilor, setul de date al produsului național brut (PNB), setul de date al produsului intern brut (PIB) anual și informațiile despre venitul zilnic al companiei în decurs de 1 an [5]. În majoritatea cazurilor, datele din seria temporală pot fi sub formă de date anuale, trimestriale, lunare sau zilnice, în funcție de stocarea și adecvarea lor de utilizare [6]. În colecția datelor din seriile de timp, este analizat caracterul adecvat al datelor utilizate. Datele din afaceri sunt în continuă schimbare, astfel încât organizațiile trebuie să găsească modalități de a le utiliza pentru a lua decizii. Pentru că va afecta schimbările care vor avea loc în afaceri. Analiza seriilor cronologice este esențială pentru ca toate întreprinderile să ia decizii de afaceri în cunoștință de cauză. Este o tehnică care poate ajuta la controlul operațiunilor curente și un instrument care poate ajuta la planificarea cu același scop în prezicerea evenimentelor viitoare [7]. Această secțiune este o colecție de 25 de lucrări de cercetare alese de diferite reviste științifice stricte, concentrându-se pe studiul articolelor conexe, folosind învățarea automată până la predicția cu privire la cursul de schimb valutar și la predicția pieței bursiere și studii care se concentrează pe îmbunătățirea sau sugerarea de noi abordări ale datelor din seria temporală. În aplicarea tehnicilor de învățare automată în prognoză prin utilizarea datelor financiare, cum ar fi ratele de schimb valutar și piața prețurilor acțiunilor. În studiile pentru efectuarea cercetărilor, cercetătorul a ales să utilizeze tehnici de învățare profundă cu memorie pe termen scurt (LSTM profund) pentru a estima rata de schimb în baht thailandez (THB) față de dolarul SUA (USD). În plus față de acest studiu pentru această cercetare, cercetătorul a ales, de asemenea, rețeaua neuronală de învățare profundă LSTM pentru prezicerea pieței prețurilor bursiere (indicele Dow Jones Industrial și indicii S și P 500).

### **Capitolul 3 Modele de clasificare și modele de predicție / Evaluarea performanțelor clasificatorilor și evaluarea performanțelor modelelor de predicție**

#### **3.1 Modele de clasificare**

3.1.1 Multilayer Perceptron (MLP): Rețeaua neuronală MLP este o formă a rețelei neuronale structurate cu mai multe straturi [8]. Există un proces de instruire supravegheat și un proces de returnare a valorilor numit „Propagare inversă”. Rețeaua neuronală MLP include trei straturi principale: stratul de intrare, stratul ascuns și stratul de ieșire [9]. Există 2 subsecțiuni pentru returnarea valorilor în rețeaua neuronală: trecere înainte și trecere înapoi. Pentru o trecere înainte, datele trec prin rețeaua neuronală la nivelul de intrare și sunt trecute de la un strat la altul până la



stratul de ieșire. La trecerea înapoi, valorile ponderii conexiunii vor fi ajustate în funcție de corectarea erorilor, ceea ce înseamnă că răspunsul real și răspunsul țintă au semnalul de eroare. Acest semnal de eroare este trimis înapoi în sistemul de rețea neuronală în direcția opusă conexiunii. Valoarea ponderii conexiunii va fi ajustată până când răspunsul real se apropie de răspunsul țintă. Principiul de funcționare al MLP este că fiecare strat al stratului ascuns are de calculat o funcție atunci când primește un semnal de la un nod din stratul anterior, numită „Funcția de activare”.

3.1.2 Support Vector Machine (SVM) este un clasificator liniar de clasa 2 care și-a recunoscut eficiența față de alte metode de clasificare [10]. Avantajul SVM este că este eficient în clasificarea datelor de dimensiuni mari. În plus față de utilizarea funcției kernel, pentru a converti datele într-o dimensiune superioară într-un spațiu caracteristic care poate clasifica efectiv datele obscure, principiul SVM constă în a găsi linia cu cea mai mare marjă (marja maximă) care poate împărți datele în două clase [11]. Modelul prezentat aici este un instrument popular de învățare automată utilizat în diferite studii de cercetare. Aceasta poate oferi o soluție atât pentru clasificarea datelor, cât și pentru analiza de regresie.

3.1.3 Arborele decizional este un model foarte popular pentru învățarea automată și care deseori realizează lucrări de ultimă generație în ceea ce privește predicțiile cutiei negre [12]. Unii arbori de decizie sunt mai populari, cum ar fi C4.5, CART, arborele stimulat și “random forest” [13]. Metoda probabilității ne permite să criptăm, să emitem ipoteze privind structura arborelui și partajarea puterii statistice între parametrii nodului. Este, de asemenea, un mecanism de prezicere a probabilității, ceea ce este important pentru aplicațiile cu semnificație cantitativă incertă.

### 3.2 Modele de predicție

3.2.1 NARX: modelul NARX (Nonlinear Autoregressive Exogenous) [14] este un model autoregresiv neliniar cu atribute de intrare exogene pentru o învățare în rețeaua neuronală dinamică recurentă cu conexiuni de feedback. Această tehnică poate crește precizia rezultatelor în învățare și predicție. Modelul NARX are două tipuri diferite de structură: arhitectură serie-paralelă (numită „buclă deschisă”) și arhitectură paralelă (numită „ciclu închis”) [15].

3.2.2 Long Short -Term Memory (LSTM). Abordarea modelului LSTM, creată de Hochreiter și Schmidhuber în 1997, rezolvă problema gradațiilor lipsă [16]. LSTM, comparativ cu mai simplul RNN, folosește celule de memorie în loc de neuroni. O celulă cu un singur stadiu este caracterizată de o arhitectură complexă constând din trei stări: intrare, ascuns și ieșire. În interiorul blocului de celule de memorie există trei unități de gateway exponențiale și reglabile: poarta de intrare, poarta uitată și poarta de ieșire [17].

### 3.3 Evaluarea performanțelor clasificatorilor și ale modelelor de predicție

3.3.1 Performanța clasificatorilor de evaluare. Pentru măsurarea performanței modelelor proiectate în această cercetare, s-a folosit o variabilă a ratei de precizie pentru a evalua performanța modelului. Calculul preciziei de testare a modelului este detaliat în următoarea ecuație [18]:

$$\text{Precizie} = \frac{TP + TN}{TP + TN + FP + FN} \times 100, \quad (3.1)$$

unde TP reprezintă numărul de solicitanți pentru “credit neadecvat” cu o valoare estimată a „creditului neadecvat”,

TN reprezintă numărul de solicitanți pentru un “credit bun” cu o valoare estimată a „creditului bun”,

FP reprezintă numărul de solicitanți de “credit bun” cu o valoare estimată a „creditului neadecvat”,

FN reprezintă numărul de solicitanți pentru “credit neadecvat” cu o valoare estimată a „creditului bun”.

3.3.2 Măsuri de evaluare a prognozei. Prezenta cercetare a ales patru feluri de măsurări ale erorii performanței pentru a testa rezultatele experimentale ale prognozei: Eroarea medie pătratică- Mean Square Error (MSE), Rădăcina pătrată a erorii medii pătratice - Root Mean Square Error (RMSE), Eroarea medie absolută procentuală - Mean Absolute Percentage Error (MAPE) și precizia [18], [19]. Aceste măsurări utilizează următoarele variabile:  $y_t$  este valoarea inițială,  $f_t$  este valoarea prezisă,  $e_t = y_t - f_t$  este eroarea de prezicere,  $n$  este amploarea setului de date de testare. Detaliile măsurilor de prognozare sunt prezentate în tabelul 3.1.

**Tab. 3.1** Măsuri ale calității predicției pentru evaluarea modelului neuronal Deep LSTM.

Forecasting measures	Equations
Eroarea medie pătratică- Mean Square Error (MSE)	$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$
Rădăcina pătrată a erorii medii pătratice- Root Mean Square Error (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$
Eroarea medie absolută procentuală- Mean Absolute Percentage Error (MAPE)	$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{ e_t }{ y_t } \times 100$
Precizie	$\left(1 - \frac{1}{n} \sum_{t=1}^n \frac{ e_t }{ y_t } \times 100\right) \times 100$

## Capitolul 4 Tehnici de selecție a caracteristicilor aplicate pentru cotarea creditelor

Prezenta cercetare urmărește să studieze selectarea, construirea și compararea rezultatelor testelor din arborele decizional și modelele SVM, folosind tehnici de selectare a caracteristicilor Principal Component Analysis (PCA) și ReliefF pentru a face modelele mai eficiente. Acest capitol explică tipurile și operațiunile de selecție a caracteristicilor - algoritmul PCA și ReliefF. Această cercetare prezintă rezultatele experimentale ale modelelor de clasificare prin compararea rezultatelor SVM cu modelul funcțiilor kernel și metoda arborelui decizional împreună cu tehnicile de selectare a caracteristicilor.

### 4.1 Specificațiile setului de date

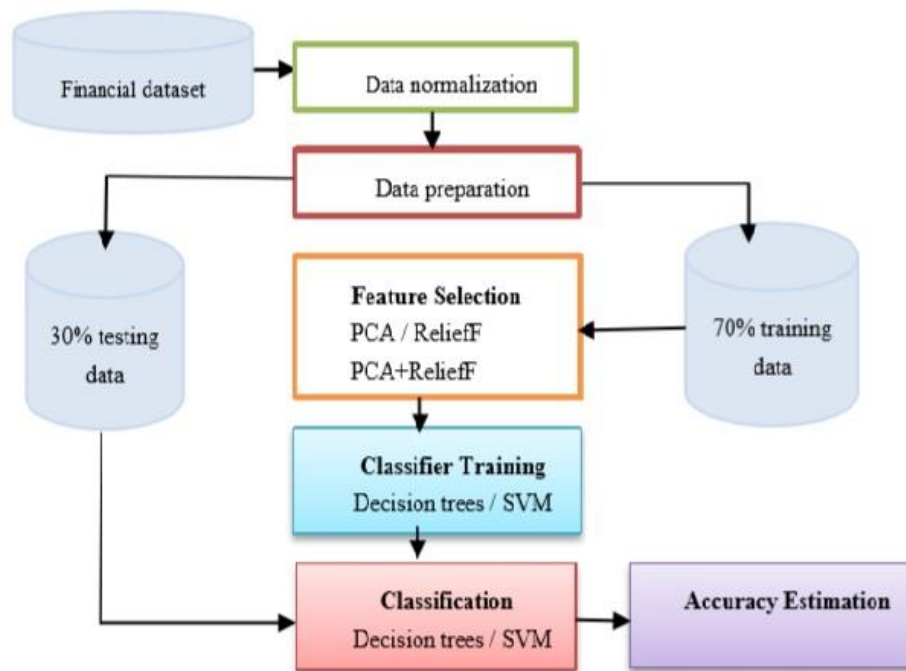
În această cercetare, modelul propus a utilizat setul de date financiare din baza de date UCI Machine Learning. În tabelul 4.1, sunt prezentate detaliile caracteristicilor setului de date de credit german.

**Tab. 4.1** Detaliile setului de date de credit german.

Numele setului de date	Numărul atributelor	Credite bune	Credit prost	Total	Clase
setului de date de credit german	25	700	300	1000	1 = bun (acceptat) 2. = rău (respins)

## 4.2 Modelele propuse de tehnici PCA și ReliefF aplicate pentru evaluarea creditelor

Modelul de clasificare prin aplicarea tehnicii de selectare a caracteristicilor prin utilizarea algoritmului PCA și ReliefF pe seturile de date financiare este redat în figura 4.1.



*Fig. 4.1 Modelul propus de selecție a caracteristicilor bazat pe PCA și ReliefF pentru evaluarea creditelor [20].*

4.2.1 Tehnica PCA. PCA este o tehnică de analiză a componentelor pentru multivariat date fără segmentare variabilă. În această tehnică ne interesează să găsim doar relațiile dintre acele variabile care vor crea o nouă variabilă constând din varianță sau varianța variabilei anterioare. Tabelul 4.2 prezintă calculul varianței rezultate utilizând tehnica PCA care implică fiecare component și afișează numărul optim de componente din setul de date de scor german de credit. Rezultatele testului pot fi definite ca fiind cel mai mic număr de elemente cu cea mai mare valoare variabilă.

4.2.2 Algoritm ReliefF. În această lucrare s-a aplicat algoritmul ReliefF pentru a găsi un subset de caracteristici candidate. Variabila  $k$  a fost setată începând cu  $k = 10$  ( $k$  fiind cel mai apropiat vecin). Rezultatele testelor de stabilitate și fiabilitate ale ratingurilor și ponderilor algoritmilor ReliefF pentru valorile  $k$  sunt prezentate în tabelul 4.3.

*Tab. 4.2 Valorile proprii, varianța în spațiul transformat PCA și varianța cumulată.*

Componenta Index	1	5	10	15	18	20	23	25
Valoare proprie	2.4602	1.6435	1.0243	0.9334	0.8002	<b>0.4832</b>	0.1283	0.1112
% Varianța în spațiul transformat de PCA	9.84	6.56	4.08	3.73	3.20	<b>1.93</b>	0.48	0.44
% Varianță cumulată	9.84	37.92	61.24	80.76	90.80	<b>95.33</b>	99.12	100.00

Pentru experimentele din tabelul 4.2 de mai sus, pe baza rezultatelor testului, folosind tehnica PCA, procentul varianței cumulative a fost de 95.33%, în concordanță cu o selecție de  $m = 20$  de componente. Valoarea proprie este 0.4832 și variația procentuală în ritmul transformat PCA este 1.93.

**Tab. 4.3** Ordonarea și ponderile caracteristicilor din setul de date de credit german.

Ranguri	Ponderi	Marcă
<b>1</b>	<b>0.1589</b>	<b>Cea mai importantă caracteristică</b>
3	0.0771	
7	0.0406	
6	0.0399	
9	0.0379	
24	0.0243	
2	0.0243	
8	0.0234	
10	0.0193	
11	0.0167	
5	0.0167	
12	0.0166	
14	0.0164	
23	0.0141	
13	0.0137	
16	0.0094	
17	0.0080	
18	0.0044	
4	0.0041	
15	0.0021	
<b>22</b>	<b>0.0004</b>	<b>Caracteristica cea mai puțin importantă</b>
21	-0.0007	
19	-0.0017	
20	-0.0027	

Tabelul 4.3 prezintă rangurile numărului predictor listate în funcție de clasamentul lor. Rezultatele acestei cercetări arată că primul predictor (cu valoarea ponderii de 0.1589) este cel mai important, iar predictorul 22 (cu valoarea ponderii de 0.0004) este cel mai puțin important. Cincisprezece caracteristici ale ponderilor mai mari au fost utilizate pentru clasificarea în funcție de distribuția ponderii parametrilor caracteristici. Totodată, au fost folosite cincisprezece caracteristici pentru a clasifica modelul pentru funcția ReliefF.

### 4.3 Performanțele modelelor

Pentru a testa diferențele dintre modele s-au folosit atât tehnici de selectare cu caracteristici, cât și tehnici de selectare fără caracteristici. Rezultatele sunt prezentate în tabelul 4.4.

**Tab. 4.4** Rezultatele testelor pentru diferite modele de clasificare și tehnici de selecție a caracteristicilor: PCA, ReliefF, PCA + ReliefF și fără tehnică de selecție a caracteristicilor.

Model clasificator	% precizie fără selectarea caracteristicilor	% Precizie cu selectarea caracteristicilor		
		PCA	ReliefF	PCA + ReliefF
SVM-RBF	75.35	76.00	86.16	85.18
<b>Decision tree-Fine tree</b>	74.00	<b>72.23</b>	<b>88.28</b>	<b>91.67</b>
Decision tree-Medium tree	<b>77.33</b>	78.00	83.00	81.67
Decision tree-Coarse tree	74.67	76.00	75.33	80.49

În tabelul 4.4 sunt comparate rezultatele modelelor de clasificare pe setul de date de credit german. Rezultatele au arătat că arbori de decizie - Fine tree are cea mai buna acuratete (91.67%), prin comparație cu celălalt. Testând toate cele trei metode, se poate concluziona că prin combinarea tehnicii PCA și a tehnicilor ReliefF se obțin cele mai bune rezultate de clasificare.

## Capitolul 5 Îmbunătățirea performanțelor tehnicii C4.5 utilizând o cascadă conținând AdaBoost și modelul MLP pentru cotarea creditelor

În acest capitol, sunt prezentați algoritmi pentru a compara performanța modelului în clasificarea datelor de notare a creditului folosind arbori de decizie C4.5, algoritmul C4.5 în cascadă cu AdaBoost și modelul MLP. În proiectarea algoritmului pentru modelul C4.5, tehnica AdaBoost a fost încorporată în model pentru a optimiza în continuare validarea punctajului creditului. Modul constă din două faze de testare cu modelele arborelui decizional: 1) clasificarea utilizând modelul arbori de decizie C4.5 și 2) proiectarea modelului utilizând tehnica AdaBoost pentru clasificarea binară (credit acceptat sau respins).

### 5.1 Specificațiile seturilor de date

În această cercetare, modelele au fost proiectate și testate folosind seturi de date de notare a creditelor din baza de date UCI Machine Learning - tabelul 5.1.

Tab. 5.1 Detaliile seturilor de date.

Numele setului de date	Atribute	Starea creditului		Total	Eticheta
		Bun	Rău		
setului de date de credit german	25	700	300	1000	1 = bun, 2 = rău
setului de date de credit australian	15	307	383	690	1 = bun, 0 = rău

În tabelul 5.2, ratele de segmentare a setul de date de instruire, set de date de testare, și validare.

Tab. 5.2 Procentele seturilor de date (instruire/validare/test).

Numele setului de date	instruire	test	validare	Total
	70%	25%	5%	
setului de date de credit german	700	250	50	1000
setului de date de credit australian	483	172	35	690

### 5.2 Tehnici C4.5 și MLP

Structura tehnicii C4.5 utilizând o cascadă conținând AdaBoost în figura 5.1. Figura 5.2 prezintă relațiile neuronale ale modelului MLP.

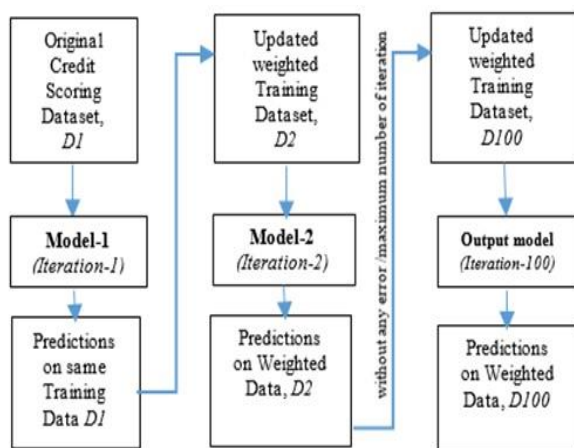


Fig. 5.1 Modelul propus constând din cascada C4.5 + AdaBoost pentru cotarea creditelor [21].




Fig. 5.2 Modelul MLP [21].

### 5.3 Rezultatele modelului propus

Tabelul 5.3 prezintă rezultatele experimentale ale clasificării scorului de credit al arborelui de decizie C4.5 și arborele de decizie C4.5 urmat de tehnica AdaBoost.

**Tab. 5.3** Rezultatele unui model de notare a creditelor cu arborele de decizie C4.5 și arborele de decizie C4.5 urmat de tehnica AdaBoost.

Numele setului de date	Modelul propus	Procentul de precizie
setului de date de credit german	C4.5	72.68
	C4.5+AdaBoost	<b>78.67</b>
setului de date de credit australian	C4.5	83.42
	C4.5+AdaBoost	<b>89.00</b>

Rezultatele indicate în tabelul 5.3 sugerează că tehnica arborelui decizional C4.5 cu tehnica AdaBoost (cu un program de 100 de iterații) obține cea mai mare valoare a predicțiilor în setul de date de evaluare a creditului german iar prin corelarea datelor detaliate de rating din Australia putem trage următoarele concluzii: Acuratețea clasificării în creditul german cu modelul algoritmul C4.5 în cascadă cu AdaBoost a fost de 78.67% comparativ cu modelul arbori de decizie C4.5, ce a condus la o precizie de doar 72.68%. Pentru creditul australian, cercetarea concluzionează că modelul algoritmul C4.5 în cascadă cu AdaBoost, a avut o precizie de 89.00%, comparativ cu modelul arbori de decizie C4.5, care a obținut o precizie de doar 83.42%. Rezultatele scorului de credit al modelului MLP sunt prezentate în tabelul 5.4.

**Tab. 5.4** Cele mai bune rezultate experimentale ale modelului de notare a creditelor MLP (atunci când este setat parametrul  $H = 6$  straturi ascunse).

Numele setului de date	numerele de neuroni de intrare	Număr optim de neuroni pentru stratul ascuns $h_1 = \dots = h_6$	Număr optim de epoci de antrenament	Procentul de precizie
setului de date de credit german	24	18	8	81.20
setului de date de credit australian	14	41	12	90.85

Rezultatele modelului MLP prezentate în tabelul 5.4 pot fi interpretate astfel: 1) Rezultatele testului modelului MLP pe baza setului de date de evaluare a creditului german au arătat că cea mai bună acuratețe a fost de 81.20%, în timp ce setul de date australiene de notare a creditelor care clasifică notarea creditelor cu modelul MLP poate duce la o precizie de clasificare de până la 90.85%. 2) Pentru a obține un model MLP care să se potrivească schemei de clasificare a ratingului de credit, este necesar să determinăm numărul optim de neuroni pentru straturile ascunse și numărul optim al etapelor de încercare, pentru a obține cea mai bună eficiență a clasificării. Tabelul 5.5 prezintă o comparație a rezultatelor testelor efectuate pe ambele modele.

**Tab. 5.5** Rezultatele comparării performanțelor modelului C4.5 (C4.5 și C4.5 urmat de tehnica AdaBoost) și ale modelului MLP.

Model	Credit german (% corect)	Credit australian (% corect)
C4.5	72.68	83.42
C4.5 +AdaBoost	78.67	89.00
MLP	<b>81.20</b>	<b>90.85</b>

Prin compararea celor mai bune performanțe ale modelelor testate au putut fi evaluate rezultatele celor două seturi de date (vezi tabelul 5.5). Se poate concluziona că modelul MLP a fost mai eficient în clasificarea datelor de notare a creditelor decât modelul arborele de decizie (arborele de decizie C4.5 și arborele de decizie C4.5 urmat de tehnica AdaBoost). Modelul MLP a avut cea mai mare precizie (81.20%) în creditul german. Și în creditul australian, modelul MLP a reușit să prezinte cea mai mare acuratețe (90.85%).

## Capitolul 6 Utilizarea unui model de rețea neuronală exogenă neliniară autoregresivă (NARX- Nonlinear Autoregressive Exogenous) pentru predicția ratei de schimb valutar

În acest capitol putem găsi câteva tehnici pentru prezicerea datelor din seriile de timp folosind modelul de rețea neuronală exogenă neliniară autoregresivă (NARX- Nonlinear Autoregressive Exogenous) pentru a prezice ratele de schimb valutar. În acest studiu, am ales să utilizăm un set de date al cursului zilnic al bahtului thailandez față de dolarul SUA (THB: USD) cu informații preluate de la Banca Thailandei, prin selectarea tuturor datelor istorice pentru un total de 10 ani. Au fost utilizate date despre unii dintre cei mai importanți indicatori economici care să fie folosiți ca input pentru a testa modelul rețelei neuronale, și anume rata inflației, rata de creștere a PIB-ului, rata dobânzii, balanța comercială și soldul contului pentru datele de intrare ale modelului neuronal NARX.

### 6.1 Specificațiile setului de date

În acest studiu am utilizat setul de date obținut de la cursul de schimb istoric al Băncii Thailandei timp de zece ani (din 2009 până în 2018), care conține o mulțime de informații importante privind cursul de schimb al bahtului thailandez față de USD. Numărul total de pași temporali din setul de date a fost de 2373 [22]. Setul de date a fost împărțit după cum urmează: 70% - seturile de instruire, 25% - seturile de test, și 5% - seturile de validare. Detaliile privind împărțirea datelor seriei temporale ale cursului de schimb sunt prezentate în tabelul 6.1.

Tab. 6.1 Volumul setului de date și procentele seturilor de instruire, validare și test.

Set de date	Cantitate	Raport (procent)
seturile de instruire	1661	70
seturile de test	593	25
seturile de validare	119	5
Total	2373	100

### 6.2 Arhitectura modelului NARX propus

Proiectarea modelului neuronal NARX [23] cu arhitectură serie-paralelă este realizată de următoarea intrare / ieșire analitică cu ajutorul ecuației 6.1.

$$\hat{y}(t+1) = F\left(y(t), y(t-1), \dots, y(t-d_y), x(t), x(t-1), \dots, x(t-d_x)\right), \quad (6.1)$$

unde  $F(\cdot)$  este funcția de cartografiere a modelului neuronal NARX;

$\hat{y}(t+1)$  este o ieșire estimată a modelului neuronal NARX în acest moment ( $t+1$ );

$y(t), y(t-1), \dots, y(t-d_y)$  sunt adevăratele valori anterioare ale valorilor de ieșire din seria temporală a modelului neuronal NARX;

$x(t+1), x(t), x(t-1), \dots, x(t-d_x)$  sunt intrările modelului neuronal NARX;

$d_x$  reprezintă numărul de întârzieri la intrare și  $d_y$  reprezintă numărul de întârzieri la ieșire.

În ecuația (6.1), din bucla deschisă pentru arhitectura serie-paralelă, valoarea viitoare a seriei temporale  $\hat{y}(t+1)$  este prezisă din valorile prezente și anterioare ale  $x(t)$  și adevăratele valori anterioare ale seriilor temporale  $y(t)$ . După cum am menționat deja, metoda propusă de predicție a seriilor temporale utilizează rețeaua neuronală NARX. Structura modelului neuronal NARX propusă este prezentată în figura 6.1.




Fig. 6.1 Arhitectura modelului neuronal NARX [24].

Am folosit date istorice pentru a testa modelul celei mai bune rețele neuronale NARX în buclă deschisă. Modelul a fost utilizat pentru a calcula un curs de schimb ca intrare pentru pasul următor în buclă închisă. Presupunem că există 3 neuroni de intrare și 1 neuron de ieșire. Numărul întârzierilor de intrare variază de la unu la trei pentru a lua în considerare valorile întârziate ale variabilelor independente și dependente. Numărul de neuroni rezultat din simularea stratului ascuns a fost 10. În figura 6.2 putem vedea modul de configurare a modelului neuronal NARX.




Fig. 6.2 Configurarea modelului neuronal NARX [24].

Tabelul 6.2 prezintă detaliile parametrilor pentru cea mai bună performanță cu cel mai mic set de intrare al modelului neuronal NARX.

Tab. 6.2 Cele mai bune rezultate ale arhitecturii modelului neuronal NARX.

Parametru	Date / Tehnică utilizată
Numărul de neuroni de intrare (s)	3
Numărul de neuroni de ieșire (s)	1
Numărul de neuroni ascunși (s)	10
Etape de timp ale datelor de antrenament, date de testare și date de validare	1661 : 593: 119
Numărul de întârzieri de intrare (d)	3
Parametru de antrenament	Error : MSE, MAPE, Learning algorithm : The scaled conjugate gradient (trainscg)
Algoritm de instruire	Feed-forward neural network

### 6.3 Rezultatele modelului propus

Pentru a atinge obiectivele cercetării, proiectarea pentru testarea modelului a fost împărțită în 3 părți:

*Partea 1 - Găsirea variabilelor importante ale datelor de intrare:* vom găsi variabilele importante ale datelor de intrare de la cinci indicatori economici: rata inflației, rata dobânzii, produsul intern brut, contul de sold și balanța comercială Pentru a completa structura modelului neuronal NARX, trebuie să studiem determinarea parametrilor importanți pentru numărul de neuroni din fiecare strat. Tabelul 6.3 prezintă rezultatele obținute la determinarea numărului de neuroni dintr-o rețea, pentru diferite straturi ale modelului neuronal NARX.



**Tab. 6.3** Rezultatele experimentale (setarea numărului de neuroni hidden (H) la 10, a numărului de întârzieri ale intrării ( $d_x$ ) și a numărului de întârzieri ale ieșirii ( $d_y$ ) la 4 ( $H = 10, d_x = d_y = 4$ ).

Numărul de intrări	Semnificația intrării	Rezultate de performanță		
		MSE	MAPE	R
2	rata dobânzii, Produsul intern brut	0.011	6.019	0.997
3	rata inflației, rata dobânzii, Produsul intern brut	<b>0.008</b>	<b>4.263</b>	<b>0.998</b>
4	rata inflației, rata dobânzii, Produsul intern brut, cont de sold	0.009	4.475	0.997
5	rata inflației, rata dobânzii, Produsul intern brut, cont de sold, balanță comercială	0.013	6.441	0.992

În tabelul 6.3 se arată cum a fost testată rețeaua neuronală pentru a se potrivi intrării și țintei cu 4 seturi de semnificație a intrării. S-a constatat că cea mai bună structură a modelului de rețea neuronală NARX propusă a fost obținută prin utilizarea a trei neuroni de intrare în stratul de intrare: rata inflației, rata dobânzii și produsul intern brut. Există 10 neuroni în stratul ascuns și 1 neuron în stratul de ieșire. Acest test a arătat faptul că întârzierile de intrare și ieșire (d) prezintă o valoare de la 1 la 4. Cele mai bune performanțe ale MSE, MAPE și R obținute cu această structură sunt 0.008, 4.263% și 0.998.

*Partea 2 - Găsirea numărului adecvat de neuroni ascunși:* găsim numărul adecvat de neuroni ascunși pentru testarea modelului neuronal NARX prin testarea a 2 grupuri: grupul 1, unde neuronul ascuns are valorile 1, 5, 10, 15, 20, 25 și 30 și grupa 2, unde neuronul ascuns este setat la 40, 50, 60, 70, 80, 90 și 100. În tabelul 6.3 se arată cum au fost selectate cele mai bune rezultate experimentale și cum a fost pregătită rețeaua pentru a se potrivi intrărilor. Am împărțit valoarea inițială a neuronului ascuns în 2 seturi: un prim set de neuroni ascunși care variază de la 1 la 30, cu un increment de 5 și un set de neuroni ascunși care variază de la 40 la 100, cu un increment de 10. Cercetarea a stabilit, de asemenea, numărul de întârzieri de intrare și ieșire (d) de la 1 la 4. Rezultatele experimentale sunt prezentate în tabelul 6.4.

**Tab. 6.4** Cele mai bune rezultate experimentale pentru un număr de intrări egal cu numărul de ieșiri  $N = 3$  (rata inflației, rata dobânzii, produsul intern brut) în funcție de numărul de neuroni ascunși  $H$  și de numărul de întârzieri ale intrării și ieșirii ( $N = 3, d_x = d_y = 1:4$ ).

Setul 1							
Neuronul ascuns	1	5	10	15	20	25	30
MSE	0.018	0.025	<b>0.012</b>	0.013	0.019	0.021	0.026
MAPE	3.396	4.010	<b>3.026</b>	3.141	3.401	4.001	4.024
R	0.997	0.995	<b>0.998</b>	0.997	0.996	0.996	0.995
Setul 2							
Neuronul ascuns	40	50	60	70	80	90	100
MSE	0.026	0.077	0.083	0.018	0.140	0.086	0.327
MAPE	4.031	4.716	4.823	3.346	5.267	4.842	6.019
R	0.995	0.988	0.988	0.996	0.978	0.986	0.949

Din tabelul 6.4 putem vedea că cea mai bună structură a modelului de rețea neuronală NARX propusă este obținută prin utilizarea a 3 neuroni în stratul de intrare (rata inflației, rata dobânzii, și produsul intern brut) cu 10 neuroni în stratul ascuns și 1 neuron în stratul de ieșire. Cele mai bune performanțe ale MSE, MAPE și R obținute folosind această structură sunt 0.012, 3.026% și 0.998.

*Partea 3 - Găsirea întârzierilor de intrare și ieșire adecvate:* A fost testat modelul neuronal NARX pentru a găsi întârzierile de intrare și ieșire corespunzătoare, întârzierile de intrare și ieșire fiind 1, 3, 4, 5, 10, 15, 20, 25 și 30. Cercetarea a fost concepută pentru a testa din nou rețeaua pentru a se potrivi intrării și țintei pentru  $d_x$  și  $d_y$ . Această sarcină trebuie să ajusteze variabila de intrare împreună cu rata inflației, rata dobânzii și produsul intern brut ( $n = 3$ ). S-a configurat numărul valorii neuronului ascuns cu 10 neuroni în stratul ascuns și 1 neuron în stratul de ieșire. Au fost

alese o serie de întârzieri de intrare  $d_x$  și  $d_y$  - 1, 2, 3, 4, 5, 10, 15, 20, 25 și 30 pentru a găsi cele mai bune rezultate pentru numărul de întârzieri de intrare. Rezultatele sunt prezentate în tabelul 6.5.

**Tab. 6.5** Rezultatele experimentale pentru  $N = 3$  intrări și  $H=10$  neuroni ascunși în funcție de numărul de întârzieri  $d_x = d_y$ .

Testul 1	$d_x = d_y$	1	2	3	4	5	10	15	20	25	30
	MSE	0.018	0.023	0.019	0.017	0.013	0.011	0.016	0.020	0.018	0.022
MAPE	3.728	3.353	3.812	3.689	3.538	3.243	3.625	3.878	3.728	3.916	
R	0.997	0.966	0.996	0.997	0.998	0.998	0.997	0.997	0.997	0.996	
Testul 2	$d_x = d_y$	1	2	3	4	5	10	15	20	25	30
	MSE	0.019	0.011	<b>0.006</b>	0.010	0.027	0.027	0.012	0.062	0.011	0.020
MAPE	3.762	3.532	<b>3.001</b>	3.318	4.526	4.523	3.738	5.216	3.158	3.892	
R	0.996	0.998	<b>0.998</b>	0.998	0.995	0.995	0.997	0.990	0.998	0.996	
Testul 3	$d_x = d_y$	1	2	3	4	5	10	15	20	25	30
	MSE	0.037	0.012	0.011	0.008	0.014	0.023	0.030	0.014	0.069	0.017
MAPE	4.524	3.623	3.562	3.018	3.745	3.923	4.126	3.748	5.518	3.845	
R	0.994	0.998	0.998	0.998	0.997	0.996	0.995	0.997	0.989	0.997	
Testul 4	$d_x = d_y$	1	2	3	4	5	10	15	20	25	30
	MSE	0.011	0.011	0.013	0.010	0.018	0.026	0.020	0.073	0.012	0.012
MAPE	3.509	3.502	3.625	3.453	3.723	3.992	3.845	5.827	3.572	3.570	
R	0.998	0.998	0.997	0.998	0.997	0.995	0.996	0.988	0.998	0.998	
Testul 5	$d_x = d_y$	1	2	3	4	5	10	15	20	25	30
	MSE	0.027	0.017	0.012	0.020	0.017	0.021	0.051	0.018	0.016	0.023
MAPE	3.992	3.855	3.552	3.946	3.853	3.962	4.346	3.915	3.623	3.986	
R	0.995	0.997	0.998	0.996	0.997	0.997	0.992	0.997	0.997	0.996	

Am folosit rezultatele din tabelul 6.5 pentru instruirea rețelei pentru a se potrivi intrării și țintei pentru întârziere  $d_x$  și  $d_y$ . Au fost făcute cinci teste (Testul 1 ... Testul 5). Cele mai bune rezultate experimentale ale modelului neuronal NARX propuse au fost obținute de 3 neuroni care au fost folosiți în stratul de intrare folosind rata inflației, rata dobânzii și produsul intern brut. Au fost 10 neuroni ( $H = 10$ ) în stratul ascuns și 1 neuron în stratul de ieșire. Cel mai bun număr de întârzieri de intrare  $d_x$  și cel mai bun număr de întârzieri de ieșire  $d_y$  este 3 ( $d_x = d_y = 3$ ). Cele mai bune valori ale eficienței lui MSE, MAPE și R sunt 0.006, 3.001% și 0.998. Detaliile sunt prezentate în tabelul 6.6.

**Tab. 6.6** Cele mai bune rezultate experimentale ( $H = 10$ ,  $d_x = d_y = 3$ ).

Numărul de intrări	Semnificația intrării	Rezultate de performanță		
		MSE	MAPE	R
3	rata inflației, rata dobânzii, Produsul intern brut	0.006	3.001	0.998

În figura 6.3 se prezintă o asociere a ratei de schimb prezise și efective pentru toate probele de testare, instruire și validare. De asemenea, se arată magnitudinea erorii exprimată ca diferență între valorile prezise și cele reale. Chiar dacă graficul sugerează cu tărie că rețeaua modelului neuronal NARX oferă o precizie corectă a cursului de schimb, trebuie totuși să justificăm această afirmație din punct de vedere cantitativ. În figura 6.4 este prezentată o histogramă de eroare cu 20 de benzi a modelului neuronal NARX pentru etapele de formare, testare și validare. Aceasta arată că erorile de potrivire a datelor sunt împrăștiate într-un interval mare în jurul valorii de zero. În această situație, putem vedea că majoritatea erorilor pot fi găsite în intervalul -0.3891 ... 0.3561, punctul de învățare având o eroare de 0.01218. Instruirea cu ajutorul algoritmului gradient conjugat scalat cu rețea neuronală feed-forward converge după mai puțin de 74 de etape. Figura 6.5 prezintă cea mai bună performanță de validare a modelului neuronal. Regresia de eroare a modelului neuronal NARX este prezentată în figura 6.6.




Fig. 6.3 Răspunsul seriei temporale pentru modelul neuronal NARX [24].




Fig. 6.4 Histogramă de eroare a modelului neuronal NARX [24].




Fig. 6.5 Cea mai bună performanță de validare a modelului neuronal NARX [14].




Fig. 6.6 Regresia de eroare a modelului neuronal NARX [24].

## Capitolul 7 Model neuronal Deep Learning Long Short-Term Memory (DLSTM) pentru predicția ratei de schimb valutar

Acest capitol demonstrează aplicarea modelului de învățare profundă pentru a prognoza datele privind rata de schimb Baht / dolar SUA. S-a studiat și testat modelul folosind aceleași date ca și în capitolul anterior. Obiectivul principal al acestui capitol este de a continua rezultatele din

capitolul anterior prin dezvoltarea unui model de învățare profundă cu modelul neuronal Deep Learning Long Short Term Term Memory (DLSTM) pentru a efectua predicții de serie temporală. Rezultatele experimentale obținute au fost comparate cu rezultatele testelor prezise anterior de modelul neuronal NARX.

### 7.1 Specificațiile setului de date pentru predicția ratei de schimb valutar


În această cercetare, pentru modelul neuronal DLSTM s-a folosit cursul istoric de schimb al bahtului thailandez față de dolarul SUA oferit de Banca Thailandei, prin selectarea datelor pentru un total de 10 ani cu informații din 10 aprilie 2009 până în 10 aprilie 2019 [25]. Tabelul 7.1 arată că setul de date privind cursul de schimb valutar are un total de 2442 de rânduri. Testele au fost efectuate pentru a compara rezultatele testelor din diferite seturi de date din seria A și seria B. În seria A datele detaliate au fost împărțite într-un raport de 80% pentru datele de instruire și 20% pentru datele de testare. În seria B setul de date a fost împărțit într-un raport de 70% pentru setul de instruire și 30% pentru setul de testare.

**Tab. 7.1** Detalii despre setul de date ale cursului de schimb valutar ale bahtului thailandez față de USD (volum de date și raporturi procentuale ale loturilor de antrenare și test).

Setul de date	raportul de instruire și testare (%)	Cantitatea de instruire: testare	Total
Seria A	80:20	1953:488	2442
Seria B	70:30	1709:732	2442

### 7.2 Modelul neuronal DLSTM propus

Structura modelului neuronal DLSTM propus este prezentată în figura 7.1.



**Fig. 7.1** Structura modelului neuronal DLSTM propus [26].

Pentru ecuația rezultată folosind modelul neuronal DLSTM, calculul prognozei este dat de:

$$\hat{y}(t+1) = F(y(t), y(t-1), \dots, y(t-d_y), x(t), x(t-1), \dots, x(t-d_x)) \quad (7.1)$$

unde  $F(\cdot)$  este funcția modelului neuronal DLSTM;

$\hat{y}(t+1)$  sunt valorile prezise din prezent și valorile anterioare ale lui  $x(t)$  și valorile adevărate anterioare ale seriei de timp  $y(t)$  la timpul  $(t+1)$ ;

$y(t), y(t-1), \dots, y(t-d_y)$  sunt adevăratele valori anterioare ale ieșirii din seria temporală;

$x(t), x(t-1), \dots, x(t-d_x)$  sunt intrările modelului neuronal DLSTM;

$d_x$  este întârzierea maximă pentru intrare și  $d_y$  este întârzierea maximă pentru ieșire.

Arhitectura modelului de rețea neuronală DLSTM are 10 straturi, așa cum se arată în tabelul 7.2.

Tab. 7.2 Detalii despre straturile modelului de rețea neuronală DLSTM.

Straturi	Descrieri
Strat de intrare	Secvența de intrare cu $m$ neuroni incluzând: rata inflației, rata dobânzii, Produsul intern brut, cont de sold, balanță comercială $\{m = 5d_x + d_y\}$ .
Straturi LSTM	3 straturi principale ale LSTM corespunzătoare următoarelor numere de neuroni pentru fiecare dintre straturile LSTM: 50, 100 și 150.
Straturi de abandon	3 straturi de abandon care corespund unui nivel de probabilitate bun cu o probabilitate de 50%.
Stratul relu	stratul Relu efectuează o operațiune de prag pentru fiecare element al datelor de intrare, unde orice valoare mai mică de zero este setată la zero.
Stratul conectat complet	1 strat complet conectat cu $N$ neuroni, stratul complet conectat acționează independent la fiecare pas de timp.
Strat de ieșire de regresie	1 ieșire de neuroni pentru predicția cursului de schimb valutar (THB: USD).

Structura modelului neuronal DLSTM este prezentată în figura 7.2.

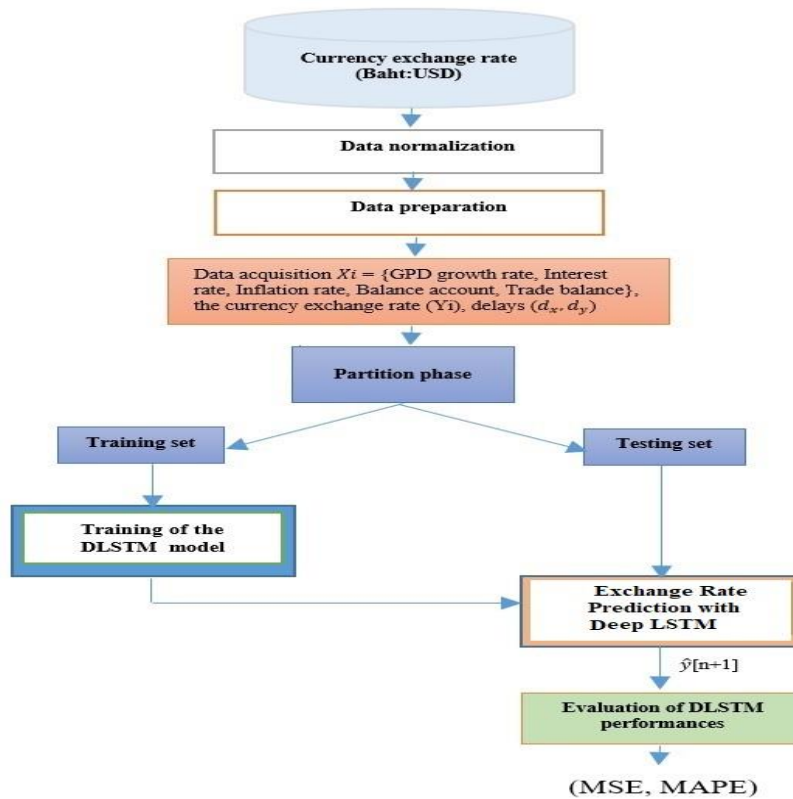


Fig. 7.2 Cadrul arhitecturii modelului neuronal DLSTM [26].

### 7.3 Rezultatele experimentale ale modelului neuronal DLSTM

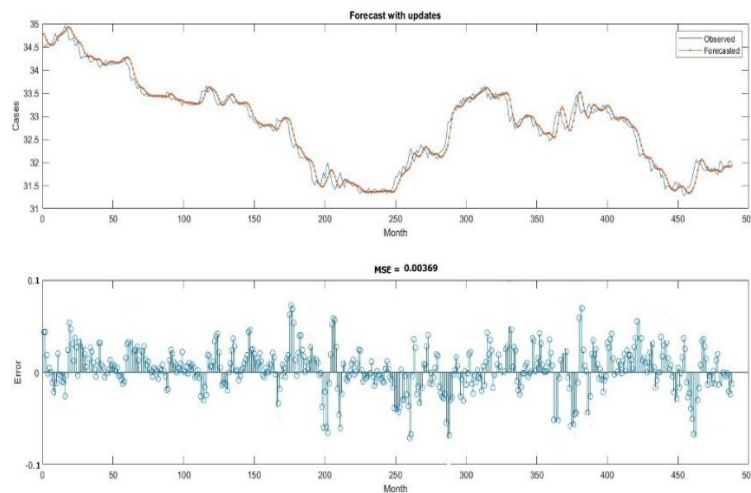
Tabelul 7.3 prezintă rezultatele instruirii modelului neuronal DLSTM pentru a se potrivească intrărilor și țințelor din seria A. Setul de date este împărțit în 80% pentru datele de instruire și 20% pentru datele de testare. Rezultatele au arătat că cea mai bună structură a modelului neuronal DLSTM constă din 3 straturi principale ale neuronale DLSTM, numărul de neuroni pentru fiecare strat LSTM fiind de 50, 100 și 150. Numărul maxim de etape și numărul maxim de iterații ale rețelei este de 250. Cel mai mare număr de întârzieri de intrare și ieșire ( $d_x, d_y$ ) este de 3 măsurători. Cea mai bună performanță a valorilor MAPE și MSE a fost 0.3122 și 0.0036. Pentru rezultatele experimentale din seria B prezentate, setul de date a fost împărțit în 70% pentru datele de antrenament și 30% pentru datele de testare. Cea mai bună structură a modelului neuronal DLSTM constă din 3 straturi principale ale neuronale DLSTM, cu un număr de neuroni pentru fiecare strat

LSTM de 50, 100 și 150. Numărul maxim de etape și numărul maxim de iterații ale rețelei este de 250. Cel mai bun număr de întârzieri de intrare și ieșire ( $d_x, d_y$ ) este 2. Rețeaua neuronală DLSTM arată că cea mai bună performanță a valorilor MAPE și MSE a fost 0.2844 și 0.0276.


**Tab. 7.3** Rezultatele experimentale ale variantelor A și respectiv B de experimente în funcție de numărul de iterații (modelul rețelei neuronale DLSTM are 3 straturi principale LSTM cu un număr corespunzător de neuroni de 50, 100 și 150).

Întârzieri	Epoci / Iteratii	Seria A (70:30)		Seria B (80:20)	
		MSE	MAPE	MSE	MAPE
$d_x = d_y = 1$	150	0.00563	0.3488	0.00532	0.3391
	200	0.00455	0.3194	0.00507	0.3405
	250	0.00433	0.3231	0.00377	0.3087
$d_x = d_y = 2$	150	0.00560	0.3472	0.00792	0.3994
	200	0.00414	0.3174	0.00379	0.3032
	250	0.00418	0.3150	<b>0.00276</b>	<b>0.2844</b>
$d_x = d_y = 3$	150	0.00534	0.4328	0.00543	0.3418
	200	0.00497	0.3343	0.00516	0.3326
	250	<b>0.00369</b>	<b>0.3122</b>	0.00333	0.2943

Figura 7.3 arată comparație între rezultatele observate și prognozate și eroarea MSE din seria A de experimente. Figura 7.4 arată comparație între rezultatele observate și prognozate și eroarea MSE din seria B de experimente.



**Fig. 7.3** Comparație între rezultatele observate și prognozate și eroarea MSE din seria A de experimente [26].



**Fig. 7.4** Comparație între rezultatele observate și prognozate și eroarea MSE din seria B de experimente [26].

## 7.4 Comparație între rezultatele modelului neuronal DLSTM și modelul neuronal NARX

Scopul principal al testării modelului neuronal DLSTM este selectarea celor mai bune rezultate experimentale din tabelul 7.3. și compararea lor cu rezultatele experimentale ale modelului neuronal NARX testat în capitolul 6 pentru prognozarea cursului de schimb valutar al bahtului thailandez față de dolarul SUA. Rezultatele comparative sunt prezentate în tabelul 7.4.

*Tab. 7.4 Comparație între rezultatele modelului neuronal DLSTM propus și modelul neuronal NARX.*

Modele	Măsurile de performanță		Referințe
	MSE	MAPE	
DLSTM	<b>0.0027</b>	<b>0.2844</b>	modelul propus
NARX	0.0060	3.0010	[24]

În tabelul 7.4, cele mai bune rezultate experimentale ale modelului neuronal DLSTM au fost comparate cu rezultatele testate anterior ale modelului neuronal NARX pentru prognozarea cursului de schimb valutar al bahtului thailandez față de dolarul SUA, prin compararea valorilor MSE și MAPE. Modelul neuronal DLSTM a avut cel mai mic MSE de 0.0027 și cel mai mic MAPE de 0.2844.

## Capitolul 8 Model neuronal Deep Learning Long-Term Memory (Deep LSTM) pentru predicția prețurilor acțiunilor

Acest capitol prezintă aplicarea modelului neuronal Deep Learning Long-Term Memory (Deep LSTM) pentru estimarea unei piețe a prețului bursier. Cercetarea a studiat și testat modelul utilizând datele despre prețurile acțiunilor de pe site-ul financiar al Yahoo. Seturile de date pentru acest studiu sunt indicele Dow Jones Industrial și indicele S și P 500. Ambele date ale seriilor temporale ale prețului acțiunilor sunt criteriile de referință cele mai utilizate pentru a determina starea unei economii pe piața de valori. De asemenea, măsoară eficiența modelului Deep LSTM și compară cele mai bune rezultate ale modelului Deep LSTM cu alte rezultate ale modelelor Deep Learning care au efectuat anterior cercetări în aceleași baze de date.

### 8.1 Specificațiile setului de date

Seturile de date privind prețurile acțiunilor sunt indicii Dow Jones Industrial și S și P 500 de pe site-ul financiar al Yahoo. Ambele seturi de date sunt din februarie 2010 până în februarie 2020. Detaliile seturilor de date sunt prezentate în tabelul 8.1.

*Tab. 8.1 Detalii despre seturile de date referitoare la prețurile acțiunilor.*

Prețurile acțiunilor Set de date	Caracteristică	Set de antrenament	Set de testare
		80%	20%
Dow Jones Industrial	open, low, high, close, adj close, volume	Februarie 2010 - Ianuarie 2018 (2012 zile)	Februarie 2018 - Februarie 2020 (499 zile)
S and P 500 Indexes	open, low, high, close, adj close, volume	Februarie 2010 - Ianuarie 2018 (2012 zile)	Februarie 2018 - Februarie 2020 (499 zile)

### 8.2 Modelul propus de rețea neuronală Deep LSTM

Această cercetare prezintă un model Deep Learning de rețea neuronală LSTM pentru a prezice prețurile zilnice ale pieței bursiere. El începe prin încărcarea seturilor de date de pe piața bursieră, urmată de dimensionarea standard și normalizarea datelor. Seturile de date despre prețul acțiunilor au fost împărțite în date de instruire și date de testare. Datele de intrare sunt utilizate pentru a asambla open data, data with high, low, closed, adjustable and closed a face prognoze zilnice ale



closing price. Modelul este evaluat pentru performanțe de eroare cu RMSE, MSE, MAPE, Precizie. Detaliile sunt prezentate în figura 8.1.

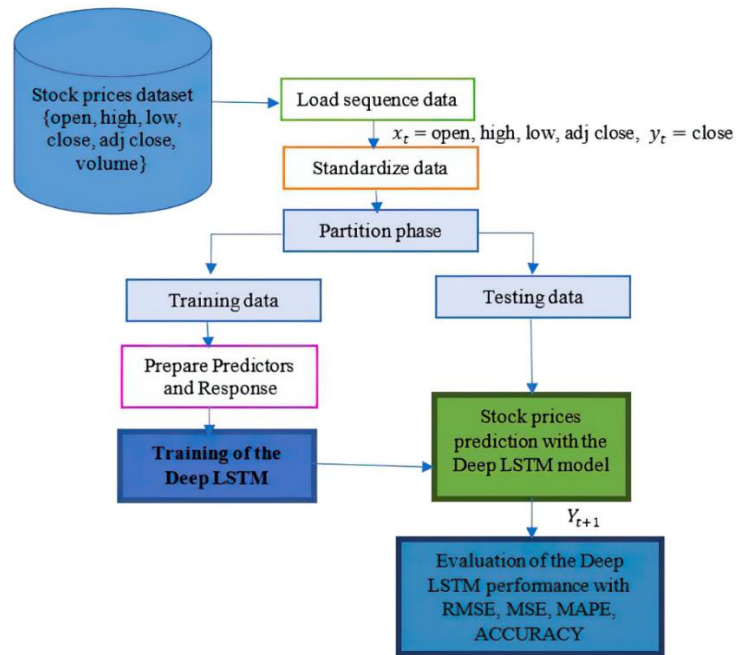


Fig. 8.1 Cadrul modelului neuronal Deep LSTM [27].

Figura 8.2 prezintă arhitectura modelului neuronal Deep LSTM cu conexiune de rețea neuronală de feedback. Datele de intrare sunt un vector cu 5 dimensiuni ( $x_t$ ) reprezentând cinci caracteristici: open, high, low, adj close, and close ( $y_t$ ). Modelul care prezice prețurile apropiate ale zilei următoare ( $Y_{t+1}$ ) este dat de

$$Y_{t+1} = \left\{ F(y_{(t)}, y_{(t-1)}, \dots, y_{(t-d_y)}, x_{(t)}, x_{(t-1)}, \dots, x_{(t-d_x)}) \right\}, \quad (8.1)$$

unde  $F(\cdot)$  este o funcție a modelului neuronal Deep LSTM,  $y_{(t)}, y_{(t-1)}, \dots, y_{(t-d_y)}$  sunt adevăratele valori ale ieșirii din seria temporală,  $x_{(t)}, x_{(t-1)}, \dots, x_{(t-d_x)}$  sunt vectorii de intrare ai modelului neuronal Deep LSTM,  $Y_{t+1}$  este valoarea prezisă a seriei temporale  $y_{(t)}$  la  $(t + 1)$  timp folosind ca intrări valorile prezente și anterioare ale  $x_{(t)}$  precum și adevăratele valori prezente și anterioare ale  $y_{(t)}$ ,  $d_x$  este întârzierea maximă de intrare,  $d_y$  este întârzierea maximă de ieșire.

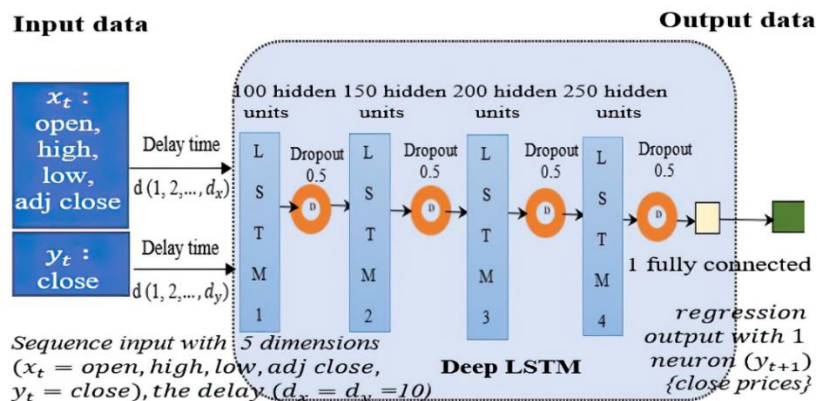


Fig. 8.2 Arhitectura modelului Deep LSTM pentru predicția prețului acțiunilor [27].



Modelul neuronal Deep LSTM are 11 straturi. Detaliile sunt prezentate în tabelul 8.2. Pentru a se adecva eficienței modelului neuronal Deep LSTM, am creat un set de opțiuni de parametri pentru instruirea rețelelor. Detaliile sunt prezentate în tabelul 8.3.

**Tab. 8.2** Detaliile straturilor modelului neuronal Deep LSTM.

Straturi	Descrieri
Stratul de intrare	Secvența de intrare cu un vector de 5 dimensiuni ( $x_t$ ) este format din cinci caracteristici: open, high, low, adj close, and close ( $y_t$ ). Acest model va prezice prețurile apropiate ale zilei următoare ( $Y_{t+1}$ ).
LSTM	Patru straturi principale de LSTM corespunzătoare numărului de neuroni pentru fiecare dintre straturile LSTM dintr-un set (100, 150, 200, 250). Numărul de epoci dintr-un set este de 10, 20, 30, 40, 50.
Stratul de abandon	Patru straturi de abandon care corespund unei probabilități rezonabile implicite de 50%.
Stratul conectat complet	Un strat complet conectat cu un neuron.
Strat de ieșire de regresie	Funcția de activare a stratului de ieșire folosește liniar ca o predicție de aproximare a valorii reale cu o ieșire de un neuron pentru predicția prețurilor închise $Y_{(t+1)}$ .

**Tab. 8.3** Parametrii modelului neuronal Deep LSTM.

Parametrii	Valoare
Optimizator	Optimizator Adam
Numărul de neuron de intrare	5-Dimensiunea matricei {open, high, low, adj close, close}
Numărul de neuron de ieșire	1Dimensiunea matricei {close}
Numărul de iterații	16 (Dimensiunea lotului este 128)
Numărul întârzierii pasului de timp	Întârzierea $d_x = d_y = 10$ .
Numărul de epoci	10, 20, 30, 40, 50
Numărul de neuroni pentru celula LSTM a fiecărui strat	100, 150, 200, 250
Rata de învățare / Programul ratei de învățare	0.001/ Piecewise

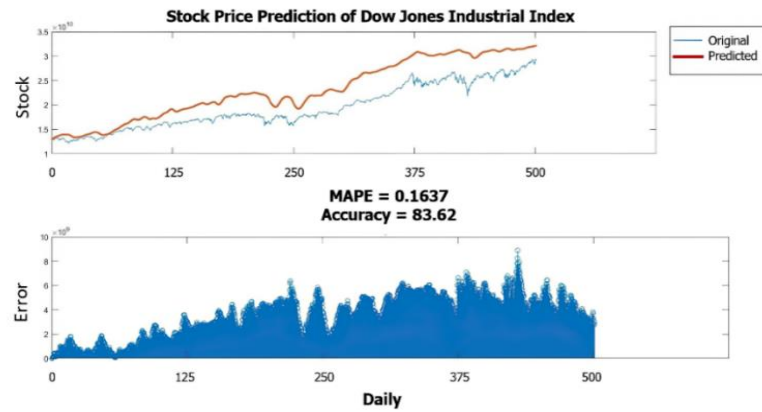
### 8.3 Rezultate experimentale ale modelului Deep LSTM

Pentru testarea modelului Deep LSTM, au fost utilizate două baze de date: Dow Jones Industrial și indexul S și P 500. Testul modelului a folosit aceiași parametri. Tabelul 8.4 prezintă rezultatele testelor modelelor pentru ambele baze de date, pentru un număr dat de neuroni de 100, 150, 200 și 250 și un număr de etape / iterații de 10, 20, 30, 40 și respectiv 50.

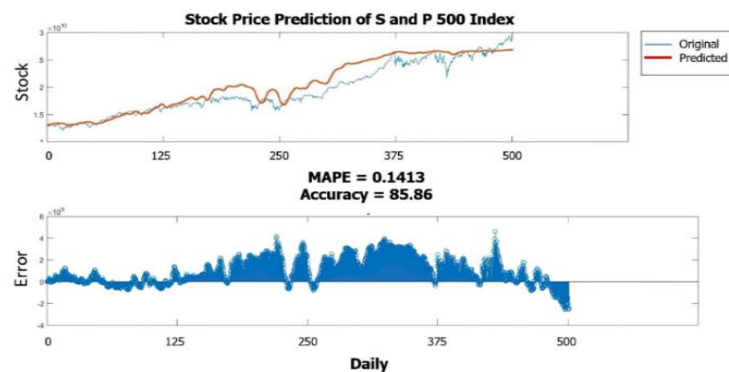
**Tab. 8.4** Rezultatele experimentale ale modelului neuronal LSTM cu 4 straturi principale LSTM corespunzătoare numărului de neuroni (100.150.200 și 250).

Denumirea istorică a prețului acțiunilor	Epoci /iterații	Măsuri de prognoză			
		RMSE	MSE	MAPE	%Accuracy
<b>Dow Jones Industrial</b>					
	<b>10</b>	<b>9.2103</b>	<b>8.4830</b>	<b>0.1637</b>	<b>83.62</b>
	20	9.1710	8.4107	0.1641	83.58
	30	9.4367	8.9052	0.1701	82.98
	40	9.5171	9.0575	0.1716	82.83
	50	12.6853	1.6091	0.2512	74.87
<b>Indici S și P500</b>					
	10	9.3511	8.7443	0.1672	83,27
	<b>20</b>	<b>8.4165</b>	<b>7.1673</b>	<b>0.1413</b>	<b>85.86</b>
	30	8.8523	7.8673	0.1559	84.40
	40	8.7039	7.5758	0.1534	84.65
	50	9.2103	8.4830	0.1637	83.62

Din tabelul 8.4. putem vedea că setul de date Dow Jones Industrial a oferit cele mai bune rezultate ale preciziei RMSE, MSE, MAPE și Forecast pentru Deep LSTM: 9.2103, 8.4830, 0.1637 și 83.62. Pe de altă parte, în setul de date index S și P 500, cele mai bune rezultate ale preciziei RMSE, MSE, MAPE și Forecast pentru Deep LSTM sunt 8.4165, 7.1673, 0.1413 și, respectiv, 85.86. Figura 8.3 și figura 8.4 prezintă cele mai bune rezultate ale modelului Deep LSTM al originalului și prețurile de închidere prevăzute ale stocului pe setul de date de testare.



*Fig. 8.3 Rezultatele comparative ale datelor originale cu prețurile de închidere prognozate pe setul de date de testare Dow Jones Industrial (precizi prognozei de 83,62%) [27].*



*Fig. 8.4 Rezultatele comparative ale datelor originale cu prețurile de închidere prognozate pe setul de date de testare al indicilor S și P 500 (precizia prognozei de 85,86% ) [27].*

#### 8.4 Rezultatele comparării modelului neuronal Deep LSTM cu alte modele

Am comparat cele mai bune rezultate ale modelului neuronal Deep LSTM cu toate celelalte cercetări și studii efectuate [28], [29] și [30], predicțiile făcându-se pe aceeași bază de date. Tabelul 8.5 arată rezultatele modelului neuronal LSTM propus, prin comparație cu alte modele pentru setul de date al indicelui Dow Jones Industrial, iar tabelul 8.6 arată rezultatele comparației modelului de rețea neuronală Deep LSTM propus cu alte modele pentru setul de date corespunzând indicilor S și P 500.

*Tab. 8.5 Rezultatele modelului neuronal LSTM propus, prin comparație cu alte modele pentru setul de date al indicelui Dow Jones Industrial.*

Model	Măsură de performanță	Referințe
	% Precizie	
Deep LSTM neural network	83.62	Modelul propus
Recurrent Embedding Kernel (REK)	71.89	[28]
Events Embedding and Technical Indicators on CNN+LSTM	69.86	[29]

Din rezultatele prezentate în tabelul 8.5, am constatat că rezultatele experimentale ale modelului de rețea neuronală Deep LSTM propus la Dow Jones Industrial obțin cea mai bună precizie (83.62%) în comparație cu alte modele de referință; REK [28] are o precizie de 71.89%, iar CNN + LSTM [29] - una de 69.86%.

*Tab. 8.6 Rezultatele comparației modelului de rețea neuronală Deep LSTM propus cu alte modele pentru setul de date corespunzând indicilor S și P 500.*

Model	Măsură de performanță	Referințe
	% Precizie	
Deep LSTM neural network	85.86	Modelul propus
Variational Autoencoder LSTM (VAE-LSTM)	84.30	[30]
Recurrent Embedding Kernel (REK)	71.43	[28]
Events Embedding and Technical Indicators on CNN+LSTM	62.02	[29]

Rezultatele experimentale privind indicele S și P 500 date în tabelul 8.6, arată că modelul de rețea neuronală Deep LSTM propus are cea mai bună precizie (85.86%) în comparație cu precizia altor modele de referință. Modelul VAE-LSTM [30] are o precizie de 84.30%, modelul REK [28] - una de 71.43%, iar modelul CNN + LSTM [29] - una de 62.02%.

## Capitolul 9 Concluziile și perspective

### 9.1 Concluzii

Această teză constă din nouă capitole, fiecare tratând tehnici de clasificare aplicate și tehnici de învățare profundă împreună cu alte tehnici de analiză a datelor de afaceri:

Capitolul 1 prezintă scopul tezei, domeniul de aplicare, obiectivele și un scurt rezumat al conținutului.

Capitolul 2 prezintă principiile algoritmilor și teoria, inclusiv lucrările conexe utilizate în această cercetare - conținut care explică semnificația conceptelor de cotare a creditului, informații de bază despre prognozarea datelor din seriile de timp și principiile de data mining și rezumă toate lucrările din studiile aferente utilizate.

Capitolul 3 prezintă tehnicile de cotare a creditelor (credit scoring) și tehnicile de predicție a seriilor temporale de date financiare pentru două tipuri de seturi de date adecvate fiecăruia din cele două demersuri: setul de date pentru cotarea creditelor și setul de date din seria temporală financiară. Tehnicile de clasificare prezintă caracteristicile modelelor folosind MLP, SVM și modelul arborelui de decizie. Modelele predictive utilizate pentru prognozarea seturilor de date financiare sunt modelul neuronal NARX și LSTM. Totodată, au fost explicați indicii de performanță pentru credit scoring și indicia de evaluare a performanței pentru predicția seriilor temporale.

Capitolul 4 descrie aplicarea tehnicilor de selecție a caracteristicilor utilizate pentru clasificarea cotarea creditelor (credit scoring). Acest capitol descrie tipurile și operațiunile de selecție a caracteristicilor, ca PCA și algoritmul ReliefF.

Capitolul 5 prezintă aplicarea modelului C4.5 (C4.5 și C4.5 urmat de tehnica AdaBoost) și a modelului MLP pentru a realiza o cotare a creditelor. Acest capitol a arătat rezultatele experimentale ale fiecărei tehnici de clasificare și comparării performanțelor modelului C4.5 (C4.5 și C4.5 urmat de tehnica AdaBoost) și ale modelului MLP.

Capitolul 6 a implementat modelul de predicție a unei serii financiare temporale cu modelul neuronal NARX pentru a prezice ratele de schimb valutar. Pentru acest studiu, modelul a fost proiectat și testat utilizând cursul zilnic baht thailandez / dolar SUA. Și acest model a folosit principalii indicatori economici și variabile macroeconomice ca intrări exogene, împreună cu rata de creștere a PIB-ului, rata dobânzii, rata inflației, contul soldului și balanța comercială pentru datele de intrare ale modelului neuronal NARX.

Capitolul 7 prezintă aplicarea unei tehnici Deep Learning pentru a prognoza cursul de schimb valutar în cadrul modelului neuronal DLSTM.

Capitolul 8 ilustrează aplicarea Deep Learning în versiunea neuronală LSTM pentru a prezice prețul bursier. Modelul a folosit date despre prețul acțiunilor de pe site-ul financiar Yahoo. Am ales două seturi de indicelui Dow Jones Industrial (DJI) și indicilor S și P 500, ambele fiind repere utilizate în mod obișnuit pentru a determina starea economiei. În ansamblu, pentru a măsura eficiența modelului neuronal Deep LSTM am comparat rezultatele modelului neuronal LSTM propus cu alte modele pentru setul de date al indicelui Dow Jones Industrial și indicilor S și P 500.

## **9.2 Perspective**

Implementarea și proiectarea modelelor de învățare automată pentru toate aplicațiile de afaceri legate de clasificarea și analiza seriilor temporale ale acestei teze sunt prezentate mai jos. Autorul speră că aceste modele pot fi adaptate pentru a găzdui și o varietate de operații care implică date. În viitor, pentru a crește eficiența modelelor de testare, putem dezvolta modelele prezentate folosind noi tehnici:

- În ceea ce privește clasificarea tehnicilor de cotare a creditelor, testarea modelelor considerate a constatat că tehnicile de selecție a caracteristicilor sunt adecvate pentru implementarea clasificării creditelor. Pentru cele mai bune experimente, rezultatele modelului pot aplica modelele de Deep Learning combinate cu tehnici de clasificare convenționale sau o combinație cu tehnici de mărire a separabilității claselor pentru o eficiență mai bună.

- După cum știm, există multe funcții nucleu care se pot aplica în tehnici de clasificare. Pentru a dezvolta modelele SVM, putem compara rezultatele propuse de clasificare SVM-RBF cu alte funcții nucleu, cum ar fi funcția polinomială, liniară sau sigmoidală.

- Din diferite studii de cercetare legate de notarea creditelor și analiza datelor din seriile de timp, s-a constatat că aplicarea modelului de clasificare și a tehnicilor de previziune a riscurilor financiare a avut o importanță capitală. Aceste două modele sunt acum o sarcină importantă, deoarece instituțiile financiare se confruntă cu concurență și provocări mai intense. În plus, toate rezultatele testelor sugerează că modelele complexe pot să nu fie întotdeauna aplicabile situațiilor din lumea reală. Prin urmare, modelul de evaluare utilizat pe scară largă este aplicat pentru a se adapta la diverse tehnici. Obținerea unei precizii mai mari a predicțiilor reprezintă o sarcină fundamentală pentru cercetările viitoare.

### 9.3 Lista contributiilor originale

- [1] **Damrongsakmethee, T.**, and Neagoe, V.-E. (2017). Data Mining and Machine Learning for Financial Analysis. *Indian Journal of Science and Technology*, 10(39), pp. 1–7. (Scopus, Q4). **DOI number** : 10.17485/ijst/2017/v10i39/119861. **Indian Journal of Science and Technology**: Scopus, Q4.
- [2] **Damrongsakmethee, T.**, and Neagoe, V.-E. (2019). Principal Component Analysis and ReliefF Cascaded with Decision Tree for Credit Scoring. *Computer Science On-Line Conference (CSOC2019): Artificial Intelligence Methods in Intelligent Algorithms*, (24-27 April 2019), Springer, vol.985, pp. 85–95. (Springer, ISI). **DOI number**: 10.1007/978-3-030-19810-7\_9 **Accession number WOS**: 000503762800009.
- [3] **Damrongsakmethee, T.**,and Neagoe, V.-E. (2019). C4.5 Decision Tree Enhanced with AdaBoost Versus Multilayer Perceptron for Credit Scoring Modeling. *Comoutational Methods in Systems and Software (CoMeSySo2019), Computational Statistics and Mathenatical Modeling Methods in Intelligent systems*, (3-5 October 2019), Springer, vol.1047, pp, 216-226. **DOI number**: 10.1007/978-3-030-31362-3\_22. **Springer** : It will be indexed in Web of Science.
- [4] **Damrongsakmethee, T.**, and Neagoe, V.-E. (2019). A Neural NARX Approach for Exchange Rate Forecasting. *11<sup>th</sup> International Conference on Electronics, Computers and Artificial Intelligence (ECAI2019)*, Pitesti, Romania (27-29 June 2019), IEEE, pp. 1-6. (IEEE Xplore, ISI) **DOI number**: 10.1109/ECAI46879.2019.9042094. **Accession number WOS**: 000569985400117.
- [5] **Damrongsakmethee, T.**, and Neagoe, V.-E. (2020). A Deep Learning Model with Long-Short Term Memory (DLSTM) for Prediction of Currency Exchange Rates. *Computer Science On-line Conference (CSOC2020): Artificial Intelligence and Bioinspired Computational Methods*, (23-26 April 2020), vol.1225, Springer, Cham. pp.484-498. **DOI number**: 10.1007/978-3-030-51971-1\_40. **Springer** : It will be indexed in Web of Science.
- [6] **Damrongsakmethee, T.**, and Neagoe, V.-E. (2020). Stock Market Prediction Using a Deep Learning Approach. *12<sup>th</sup> International Conference on Electronics, Computers and Artificial Intelligence (ECAI2020)*, Bucharest, Romania (25-27 June 2020),IEEE,pp.1-6. **DOI number**: 10.1109/ECAI50035.2020.9223142. **IEEE Xplore**:\_It will be indexed in Web of Science.

### Referințe

- [1] J. Marquez, “An Introduction to Credit Scoring For Small and Medium Size Enterprises .,” no. February, pp. 1–47, 2008.
- [2] A. Tealab, “Time Series Forecasting using Artificial Neural Networks Methodologies : A Systematic Review,” *Futur. Comput. Informatics J.*, vol. 3, no. 2, pp. 334–340, 2018, doi: 10.1016/j.fcij.2018.10.003.
- [3] A. Tarsauliya, R. Kala, R. Tiwari, and A. Shukla, “Financial Time Series Forecast Using Neural Network Ensembles,” *Int. Conf. Swarm Intell.*, vol. 6728, no. February 2015, pp. 480–488, 2011, doi: 10.1007/978-3-642-21515-5.
- [4] A. Dingli and K. S. Fournier, “Financial Time Series Forecasting – A Machine Learning Approach,” *Mach. Learn. Appl. An Int. J.*, vol. 4, no. 1, pp. 1–27, 2017, doi: 10.5121/mlaij.2017.4302.

- [5] K. Chapagain, S. Kittipiyakul, and P. Kulthanavit, "Short-term electricity demand forecasting: Impact analysis of temperature for Thailand," *Energies*, vol. 13, no. 10, pp. 1–29, 2020, doi: 10.3390/en13102498.
- [6] T. Damrongsakmethee and V.-E. Neagoe, "Data Mining and Machine Learning for Financial Analysis," *Indian J. Sci. Technol.*, vol. 10, no. 39, pp. 1–7, 2017, doi: 10.17485/ijst/2017/v10i39/119861.
- [7] V. Caggese, "Forecasting Exchange Rates : a Comparative Analysis Faculty of Economics," *Int. J. Bus. Soc. Sci.*, vol. 3, no. 10, pp. 145–156, 2012.
- [8] Y.-A.-K. Al-hroot, "Bankruptcy Prediction Using Multilayer Perceptron Neural Networks In Jordan," *Eur. Sci. J.*, vol. 12, no. 4, pp. 425–435, 2016, doi: 10.19044/esj.2016.v12n4p425.
- [9] P. Marius-Constantin, V. E. Balas, L. Perescu-Popescu, and N. Mastorakis, "Multilayer perceptron and neural networks," *WSEAS Trans. Circuits Syst.*, vol. 8, no. 7, pp. 579–588, 2009.
- [10] J. Han, M. Kamber, and J. Pei, *Data Mining Concepts and Techniques*. Elsevier Inc., 2012.
- [11] A.-D. Pietersma, "Feature Space Learning in Support Vector Machines through Dual Objective optimization Auke-Dirk Pietersma," 2010.
- [12] J. R. Quinlan, "Induction of Decision Trees," *Mach. Learn.*, pp. 81–106, 1986.
- [13] J. R. Quinlan, "Improved Use of Continuous Attributes in C4 . 5," *J. Artif. Intell. Res.*, vol. 4, no. March, pp. 77–90, 1996.
- [14] Z. Boussaada, O. Curea, A. Remaci, H. Camblong, and N. M. Bellaaj, "A nonlinear autoregressive exogenous (NARX) neural network model for the prediction of the daily direct solar radiation," *Energies*, vol. 11, no. 3, 2018, doi: 10.3390/en11030620.
- [15] J. Buitrago and S. Asfour, "Short-Term Forecasting of Electric Loads Using Nonlinear Autoregressive Artificial Neural Networks with Exogenous Vector Inputs," pp. 1–24, 2017, doi: 10.3390/en10010040.
- [16] D. Shah, W. Campbell, and F. H. Zulkernine, "A Comparative Study of LSTM and DNN for Stock Market Forecasting," in *2018 IEEE International Conference on Big Data (Big Data)*, 2018, pp. 4148–4155, doi: 10.1109/BigData.2018.8622462.
- [17] W. S. Jhang, S.-E. Gao, C.-M. Wang, and M.-C. Hsieh, "Share Price Trend Prediction Using Attention with LSTM Structure," in *20th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing, (SNPD 2019)*, 2019, pp. 208–211, doi: 10.1109/SNPD.2019.8935806.
- [18] J. S. Armstrong, "Evaluating Forecasting Methods," in *Principles of Forecasting: A Handbook for Researchers and Practitioners*, 2001, pp. 1–26.
- [19] M. Shcherbakov, A. Brebels, and A. Tyukov, "A Survey of Forecast Error Measures," *World Appl. Sci. J.* 24, no. March 2016, pp. 171–176, 2013, doi: 10.5829/idosi.wasj.2013.24.itmies.80032.
- [20] T. Damrongsakmethee and V.-E. Neagoe, "Principal Component Analysis and ReliefF Cascaded with Decision Tree for Credit Scoring," *Comput. Sci. On-line Conf. Artif. Intell. Methods Intell. Algorithms*, vol. 2, no. May 2019, pp. 85–95, 2019, doi: [https://doi.org/10.1007/978-3-030-19810-7\\_9](https://doi.org/10.1007/978-3-030-19810-7_9).
- [21] T. Damrongsakmethee and V.-E. Neagoe, "c4.5 Decision Tree Enhanced with AdaBoost Versus Multilayer Perceptron for Credit Scoring Modeling," in *3rd Computational Methods in Systems and Software*, 2019, pp. 216–226.
- [22] "Exchange rate," *Bank of Thailand*, 2019. [https://www.bot.or.th/english/\\_layouts/application/exchangerate/exchangerate.aspx](https://www.bot.or.th/english/_layouts/application/exchangerate/exchangerate.aspx) (accessed Apr. 09, 2019).
- [23] C. L. Cocianu and M.-S. Avramescu, "New Approaches of NARX-Based Forecasting Model. A Case Study on CHF-RON Exchange Rate," *Inform. Econ.*, vol. 22, no. 2/2018, pp. 5–13, 2018, doi: 10.12948/issn14531305/22.2.2018.01.
- [24] T. Damrongsakmethee and V.-E. Neagoe, "A Neural NARX Approach for Exchange Rate Forecasting," in *11th Edition Electronics, Computers and Artificial Intelligence (ECAI), Pitesti, "Romania,"* 2019, pp. 1–6.
- [25] "Historical Foreign Exchange Rates," *Bank of Thailand*, 2019. [https://www.bot.or.th/english/\\_layouts/application/exchangerate/exchangerate.aspx](https://www.bot.or.th/english/_layouts/application/exchangerate/exchangerate.aspx). (accessed Sep. 05, 2019).
- [26] T. Damrongsakmethee and V. E. Neagoe, "A Deep Learning Model with Long Short-Term Memory (DLSTM) for Prediction of Currency Exchange Rates," in *Computer Science On-line Conference (CSOC 2020): Artificial Intelligence and Bioinspired Computational Methods*, 2020, pp. 484–498.

- [27] T. Damrongsakmethee and V. E. Neagoie, “Stock Market Prediction Using a Deep Learning Approach,” in *12th International Conference on Electronics, Computers and Artificial Intelligence (ECAI2020)*, 2020, pp. 1–6.
- [28] L. Le and Y. Xie, “Recurrent Embedding Kernel for Predicting Stock Daily Direction,” in *5th IEEE/ACM International Conference on Big Data Computing, Applications and Technologies (BDCAT 2019)*, 2019, pp. 160–166, doi: 10.1109/BDCAT.2018.00027.
- [29] P. Oncharoen and P. Vateekul, “Deep Learning for Stock Market Prediction Using Event Embedding and Technical Indicators,” in *5th International Conference on Advanced Informatics: Concepts Theory and Applications (ICAICTA 2018)*, 2018, pp. 19–24, doi: 10.1109/ICAICTA.2018.8541310.
- [30] C. Gu, H. Hsieh, C. Wu, R. Chang, and J. Ho, “A Fund Selection Robo-Advisor with Deep-learning Driven Market Prediction.,” in *IEEE International Conference on Systems, Man and Cybernetics (SMC 2019)*, 2019, pp. 2845–2850.